



DETECTION OF DAMAGE IN STEEL TRUSS BRIDGES USING A HYBRID 1DCNN–BiGRU MODEL AND TIME-SERIES DATA AUGMENTATION TECHNIQUES

Nguyen Le Minh Dang, Ho Xuan Nam*, Vu Manh Trung, Nguyen Kieu Ngoc Bao

University of Transport and Communications, No 3 Cau Giay Street, Hanoi, Vietnam

ARTICLE INFO

TYPE: Research Article

Received: 06/09/2025

Revised: 10/11/2025

Accepted: 11/12/2025

Published online: 15/12/2025

<https://doi.org/10.47869/tcsj.76.9.11>

* Corresponding author

Email: hxnam@utc.edu.vn; Tel: +84978918968

Abstract. Structural health monitoring (SHM) systems based on time-series data are pivotal tools for assessing the safety and serviceability of bridges. However, the lack of large-scale and diverse datasets often leads deep learning (DL) models to overfitting and poor generalization. This study proposes a comprehensive damage detection framework that simultaneously addresses both data and model aspects. On the data side, we employ data augmentation (AUG) techniques—including noise injection, sequence reversal, flipping, and window slicing—to expand and diversify the training set. Regarding the proposed methodology, we established a hybrid deep learning framework that integrates One-dimensional Convolutional Neural Networks (1DCNN) with Bidirectional Gated Recurrent Units (BiGRU). In this architecture, the 1DCNN layers are responsible for mining local features from raw time-series inputs, while the BiGRU layers specialize in capturing long-term temporal dependencies in both directions. The efficacy of this approach was verified using the Cua Rao steel truss bridge dataset. The experimental outcomes reveal that the data-augmented hybrid model significantly outperforms standalone baselines, achieving an accuracy of 93.9%. This is a substantial improvement over the individual 1DCNN (84.2%) and BiGRU (83.8%) models, demonstrating faster convergence and high stability for SHM applications.

Keywords: Structural health monitoring; deep learning; one-dimensional convolutional neural network; bidirectional gated recurrent unit; data augmentation.

@ 2025 University of Transport and Communications



PHÁT HIỆN HƯ HỎNG CẦU GIÀN THÉP SỬ DỤNG MÔ HÌNH LAI 1DCNN-BIGRU VÀ KỸ THUẬT TĂNG CƯỜNG DỮ LIỆU CHUỖI THỜI GIAN

Nguyễn Lê Minh Đăng, Hồ Xuân Nam*, Vũ Mạnh Trung, Nguyễn Kiều Ngọc Bảo

Trường Đại học Giao thông vận tải, Số 3 Cầu Giấy, Hà Nội, Việt Nam

THÔNG TIN BÀI BÁO

CHUYÊN MỤC: Công trình khoa học

Ngày nhận bài: 06/09/2025

Ngày nhận bài sửa: 10/11/2025

Ngày chấp nhận đăng: 11/12/2025

Ngày xuất bản Online: 15/12/2025

<https://doi.org/10.47869/tcsj.76.9.11>

* Tác giả liên hệ

Email: hxnam@utc.edu.vn; Tel: +84978918968

Tóm tắt. Trong công tác quản lý chất lượng cầu, các giải pháp theo dõi sức khỏe công trình sử dụng dữ liệu biến thiên theo thời gian giữ vị trí trọng yếu. Mặc dù vậy, sự khan hiếm nguồn dữ liệu mẫu lớn và phong phú thường khiến các thuật toán học sâu rơi vào tình trạng học vẹt (overfitting) cũng như hạn chế khả năng thích nghi. Bài báo này giới thiệu một chiến lược toàn diện nhằm giải quyết song song bài toán về dữ liệu và mô hình. Về khía cạnh dữ liệu, chúng tôi triển khai phương pháp làm giàu dữ liệu thông qua các kỹ thuật như nạp nhiễu, đảo ngược chuỗi, lật và trích xuất cửa sổ để đa dạng hóa không gian mẫu. Về khía cạnh thuật toán, nghiên cứu xây dựng kiến trúc lai ghép giữa Mạng nơ-ron tích chập một chiều chịu trách nhiệm khai thác đặc trưng cục bộ, và Mạng hồi quy cổng hai chiều chuyên biệt trong việc nắm bắt các quy luật phụ thuộc dài hạn. Kiểm nghiệm thực tế trên cầu giàn thép Cửa Rào cho thấy, mô hình lai tích hợp AUG đạt hiệu năng vượt trội với độ chính xác 93,9%. Kết quả này cao hơn hẳn so với các mô hình cơ sở độc lập như 1DCNN (84,2%) hay BiGRU (83,8%), đồng thời minh chứng được tốc độ hội tụ nhanh và tính ổn định cao trong ứng dụng SHM.

Từ khóa: Giám sát sức khỏe kết cấu, học sâu, mạng nơ ron tích chập một chiều, mạng đơn vị hồi quy có cổng hai chiều, kỹ thuật tăng cường dữ liệu.

@ 2025 Trường Đại học Giao thông vận tải

1. ĐẶT VẤN ĐỀ

Trong mạng lưới giao thông, cầu là công trình giữ vai trò huyết mạch giúp kết nối các khu

vực bị chia cắt bởi địa hình tự nhiên như sông ngòi hay thung lũng. Sự hiện diện của các công trình này không chỉ là động lực cho phát triển kinh tế thông qua việc lưu thông hàng hóa mà còn cải thiện đáng kể đời sống xã hội. Mặc dù vậy, trong quá trình khai thác, kết cấu cầu liên tục chịu ảnh hưởng bởi tải trọng xe chạy và sự xâm thực từ môi trường (biến thiên nhiệt độ, gió, độ ẩm). Những tác nhân bất lợi này là nguyên nhân chính dẫn đến sự suy giảm chất lượng công trình, gây ra các rủi ro về an toàn và thiệt hại kinh tế [1], [2]

SHM là một hệ thống công nghệ toàn diện dùng để theo dõi và đánh giá tình trạng an toàn và hiệu suất của một công trình theo thời gian thực hoặc định kỳ [3], [4], [5]. Hệ thống này bao gồm việc lắp đặt các loại cảm biến khác nhau lên công trình (ví dụ: cầu, tòa nhà, đập thủy điện) để thu thập dữ liệu về các thông số như: biến dạng và ứng suất, dao động và gia tốc, nhiệt độ, chuyển vị thông qua dữ liệu chuỗi thời gian.

Dữ liệu chuỗi thời gian được định nghĩa là tập hợp các dữ liệu quan sát được sắp xếp theo trình tự thời gian, trong đó mỗi giá trị gắn liền với một mốc thời gian xác định. Loại hình dữ liệu này có tính ứng dụng đa dạng, trải dài từ tài chính, khoa học đến kỹ thuật công trình. Tuy nhiên, trong điều kiện vận hành thực tế, dữ liệu thu thập từ hệ thống quan trắc thường xuyên đối mặt với vấn đề khuyết thiếu. Nguyên nhân chủ yếu xuất phát từ hư hỏng cảm biến, gián đoạn đường truyền hoặc lỗi phần mềm. Hệ quả là dẫn đến sai lệch trong phân tích và gián đoạn giám sát; đặc biệt trong lĩnh vực SHM, sự thiếu hụt thông tin tại các thời điểm tới hạn có thể làm bỏ sót các hư hỏng nguy cấp. Do đó, việc tái tạo dữ liệu bị mất là yêu cầu tiên quyết để đảm bảo độ tin cậy của hệ thống. Hiện nay, các mô hình Học sâu (DL) đã nổi lên như một giải pháp ưu việt để xử lý hiệu quả các chuỗi thời gian phức tạp này [6], [7].

DL là một phân nhánh chuyên sâu của học máy, vận hành dựa trên kiến trúc mạng nơ-ron đa lớp nhằm giải quyết các cấu trúc dữ liệu phi tuyến. Nhờ cơ chế tự trích xuất đặc trưng từ dữ liệu gốc, DL đã khẳng định ưu thế vượt trội trong phân tích chuỗi thời gian, đặc biệt với các tập dữ liệu quy mô lớn [8], [9]. Trong đó, mạng nơ-ron tích chập một chiều (1DCNN) và mạng hồi quy Gated Recurrent Unit hai chiều (BiGRU) được đánh giá là những kiến trúc tối ưu để xử lý hiệu quả các bài toán về dữ liệu chuỗi thời gian.

Mạng nơ-ron tích chập một chiều (1DCNN) là kiến trúc chuyên biệt được xây dựng để xử lý dữ liệu dạng chuỗi hoặc cấu trúc một chiều [10]. Thông qua cơ chế lọc tích chập, thuật toán này tự động trích xuất các đặc trưng cục bộ, mang lại hiệu quả cao trong nhận diện mẫu và phân loại [11]. một biến thể tối ưu của mạng nơ-ron hồi quy (RNN), được phát triển nhằm nâng cao hiệu suất xử lý chuỗi so với các phương pháp RNN kinh điển. Sức mạnh của BiGRU nằm ở khả năng nắm bắt ngữ cảnh toàn diện nhờ cơ chế lan truyền thông tin theo hai chiều thời gian [12], [13]. Tuy nhiên, 1DCNN gặp hạn chế trong việc nắm bắt các mối quan hệ phụ thuộc dài hạn trong chuỗi, một hạn chế mà kiến trúc BiGRU có thể khắc phục tốt nhờ khả năng xem xét cả ngữ cảnh quá khứ và tương lai của dữ liệu. Ngược lại, BiGRU tồn tại nhược điểm về độ phức tạp thuật toán và yêu cầu tài nguyên tính toán lớn hơn các mô hình một chiều, nhất là với bộ dữ liệu lớn. Thêm vào đó, khả năng song song hóa thấp gây trở ngại cho tốc độ huấn luyện và mô hình này không tối ưu cho dữ liệu phi tuần tự.

Để khắc phục các hạn chế riêng lẻ của 1DCNN và BiGRU, nghiên cứu đề xuất mô hình kết hợp 1DCNN–BiGRU với kỹ thuật tăng cường dữ liệu (AUG) nhằm tận dụng ưu điểm của cả hai và nâng cao khả năng khái quát. Trong đó, 1DCNN đóng vai trò bộ trích xuất đặc trưng cục bộ mạnh mẽ, làm nổi bật các mẫu tín hiệu hữu ích và giảm nhiễu nền; BiGRU tiếp nhận chuỗi đặc trưng này và mô hình hóa phụ thuộc dài hạn theo hai chiều, giúp nắm bắt động lực tín hiệu ổn định hơn. Trước khi huấn luyện, AUG được áp dụng để mở rộng và đa dạng hóa dữ

liệu, bao gồm thêm nhiễu, đảo ngược/lật, cắt ghép cửa sổ. Sự phối hợp này giúp mô hình hội tụ nhanh hơn, ít quá khớp, và dự đoán chính xác hơn, đặc biệt trong bài toán phát hiện bất thường từ tín hiệu cảm biến trong hệ thống SHM.

Bài viết này được cấu trúc thành năm phần chính, như sau: Ngoài phần giới thiệu ban đầu, phần thứ hai đưa ra mô tả về mô hình đơn lẻ 1DCNN, BiGRU và mô hình kết hợp 1DCNN-BiGRU. Phần thứ ba cung cấp thông tin về cầu Cửa Rào, cách mô phỏng bằng mô hình số cùng với cách tiền xử lý dữ liệu được sử dụng trong nghiên cứu. Phần thứ tư trình bày kết quả thu được từ nghiên cứu. Phần cuối cùng tóm tắt những phát hiện và kết quả chính của nghiên cứu.

2. PHƯƠNG PHÁP

2.1. Mạng nơ-ron tích chập một chiều – 1DCNN

Mạng 1DCNN là công cụ đắc lực trong xử lý dữ liệu tuần tự, được ứng dụng rộng rãi trên các lĩnh vực như nhận dạng giọng nói, xử lý tín hiệu âm thanh và chẩn đoán lỗi trong chuỗi thời gian [14]. Thông qua việc vận dụng các lớp tích chập và lớp gộp, 1DCNN thực hiện cơ chế học và trích xuất các đặc trưng quan trọng từ dữ liệu một chiều, hỗ trợ nhận diện các mẫu hình phức tạp và tối ưu hóa hiệu suất trong các nhiệm vụ phân loại và dự báo.

Hiệu quả vận hành của mô hình 1DCNN xuất phát từ việc thực thi các phép toán giản lược hơn so với các tính toán ma trận phức tạp, giúp giảm thiểu đáng kể thời gian xử lý. Tuy nhiên, để phát huy tối đa tiềm năng, 1DCNN yêu cầu tập dữ liệu huấn luyện quy mô lớn. Đồng thời, việc hiệu chỉnh các siêu tham số như kích thước bộ lọc, số lượng lớp tích chập và hàm kích hoạt đóng vai trò then chốt trong việc đảm bảo độ chính xác của mô hình [15].

2.2. Mạng đơn vị hồi quy có cổng hai chiều – BiGRU

Mạng GRU đề xuất bởi Cho và các cộng sự và phát triển thêm bởi Chung và các cộng sự [16] nhằm giảm hiện tượng vanishing gradient trong các mạng RNN bằng cơ chế "cổng" gọn nhẹ hơn LSTM. Khác với LSTM, GRU không có trạng thái cell riêng; toàn bộ thông tin được lưu trong trạng thái ẩn h_t và luồng thông tin được điều tiết bởi hai cổng: cổng cập nhật z_t (kết hợp vai trò "quên" và "ghi") và cổng đặt lại r_t (quyết định mức độ "quên" trạng thái quá khứ khi trích xuất đặc trưng mới). Cơ chế cổng của mô hình được tính như sau:

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z), \quad (1)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r), \quad (2)$$

$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (3)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (4)$$

Trong đó, x_t là đầu vào tại thời điểm t , $\sigma(\cdot)$ là sigmoid, \odot là nhân Hadamard. z_t điều chỉnh mức giữ lại thông tin cũ (z_t nhỏ) hay ghi đè bằng thông tin mới (z_t lớn); r_t kiểm soát mức tái sử dụng trạng thái quá khứ khi tính \tilde{h}_t .

Có thể thấy, GRU có ít tham số hơn LSTM, huấn luyện nhanh hơn, đỡ quá khớp hơn khi dữ liệu hạn chế, nhưng vẫn mô hình hóa được phụ thuộc dài hạn nhờ cơ chế cổng [17]. Tuy nhiên với các chuỗi rất dài hoặc kiến trúc rất sâu, GRU vẫn có thể chịu ảnh hưởng suy giảm gradient; khi đó BiGRU nổi lên như một phương pháp thay thế mới.

BiGRU là biến thể hai chiều của GRU, xử lý chuỗi theo cả chiều tiến và chiều lùi để khai thác đồng thời ngữ cảnh quá khứ lẫn tương lai gần tại mỗi thời điểm t . Mỗi nhánh (tiến và lùi) dùng hai cổng cập nhật z_t và đặt lại r_t nhằm giảm biến mất gradient và duy trì thông tin dài hạn

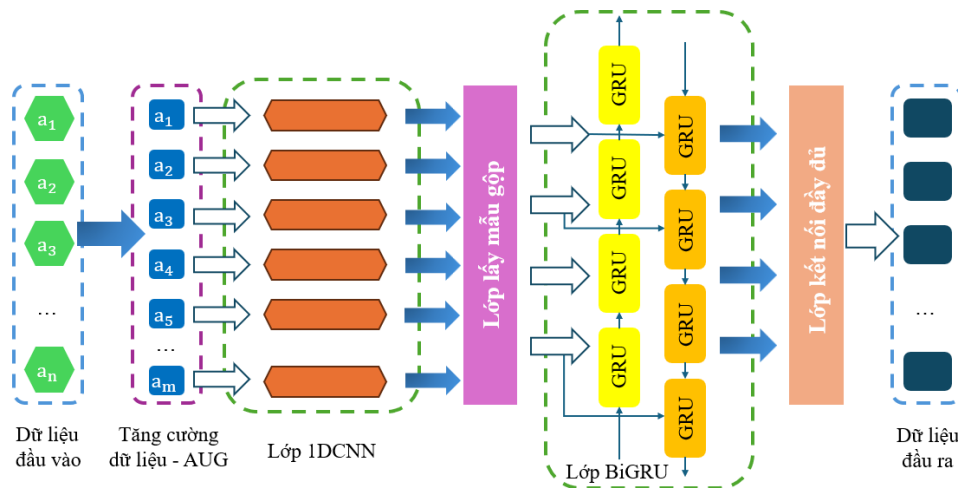
với số tham số gọn hơn LSTM. Với nhánh tiến \vec{h}_t , các cổng sẽ hoạt động y hệt GRU và nhánh lùi \overleftarrow{h}_t được tính tương tự theo trật tự thời gian đảo ngược. Đầu ra tại thời điểm t là phép nối hai trạng thái ẩn:

$$h_t = [\vec{h}_t; \overleftarrow{h}_t] \quad (5)$$

Nhờ khai thác ngữ cảnh hai chiều, BiGRU biểu diễn tốt phụ thuộc dài hạn và các mô thức thời gian dịch chuyển, hữu ích cho tín hiệu dao động/biến dạng. Khi đặt sau 1DCNN, 1DCNN trích xuất đặc trưng cục bộ còn BiGRU mô hình hóa động lực toàn cục, từ đó tăng độ chính xác phân loại hư hỏng và độ ổn định huấn luyện.


2.3. Mạng học sâu đề xuất 1DCNN-BiGRU và kỹ thuật tăng cường dữ liệu-AUG

Tuy có nhiều ưu điểm và được hữu dụng trong các bài toán về SHM, các mạng đơn lẻ vẫn không tránh được các hạn chế. Mạng 1DCNN thể hiện nhược điểm ở khả năng nắm bắt mối quan hệ phụ thuộc dài hạn của dữ liệu cảm biến, vốn rất quan trọng để xác định các thay đổi tinh vi và tích lũy theo thời gian. Mạng BiGRU khắc phục hạn chế của 1DCNN bằng cách xử lý dữ liệu chuỗi theo cả hai hướng, cho phép mô hình nắm bắt hiệu quả mối quan hệ phụ thuộc dài hạn và các dấu hiệu hư hỏng tinh vi. Tuy nhiên, kiến trúc tuần tự của BiGRU dẫn đến tốc độ xử lý chậm hơn đáng kể, gây khó khăn cho việc huấn luyện với các bộ dữ liệu lớn và phức tạp.



Hình 1. Kiến trúc mạng của mô hình đề xuất.

Dựa trên những phân tích về ưu nhược điểm đã nêu, nghiên cứu này đề xuất kiến trúc mạng lai ghép 1DCNN-BiGRU ứng dụng cho bài toán chẩn đoán hư hỏng trong SHM, nhằm khai thác tối ưu sức mạnh cộng hưởng của cả hai mô hình. Trong cơ chế này, tầng 1DCNN đóng vai trò trích xuất tự động các đặc trưng cục bộ từ tín hiệu cảm biến thô, tạo tiền đề cho tầng BiGRU tiếp nhận và phân tích các phụ thuộc phi tuyến dài hạn theo trục thời gian. Sự phối hợp này cho phép hệ thống đồng thời nhận diện các biến động vi mô tức thời và nắm bắt các quy luật biến đổi vĩ mô của kết cấu, qua đó cải thiện đáng kể độ chính xác và tính tin cậy của kết quả chẩn đoán. Cấu trúc chi tiết của mô hình đề xuất được minh họa trực quan tại Hình 1.



Hình 2. Kỹ thuật tăng cường dữ liệu - AUG.

Hơn nữa, để cải thiện dữ liệu chúng tôi đề xuất kỹ thuật tăng cường dữ liệu AUG gồm lật đảo chuỗi, thêm nhiễu ngẫu nhiên và cắt ghép cửa sổ. Ba thao tác này giúp mở rộng và đa dạng hóa tập huấn luyện, tăng bền vững trước nhiễu, giảm quá khớp và cải thiện khả năng khái quát của mô hình.

Ưu điểm nổi bật của mô hình này nằm ở khả năng tích hợp hiệu quả giữa các khối chức năng. Kỹ thuật AUG được sử dụng trong giai đoạn tiền xử lý dữ liệu để làm phong phú tập dữ liệu hư hỏng (thường là dữ liệu hiếm), từ đó nâng cao tính tổng quát hóa và giảm thiểu nguy cơ quá khớp. Tiếp theo, mạng 1DCNN đảm nhận vai trò trích xuất các đặc trưng cục bộ và bất biến theo thời gian, đặc biệt hữu ích trong việc nhận diện các dấu hiệu nhỏ hoặc đột ngột. Sau đó, khối BiGRU xử lý các đặc trưng này để nắm bắt các quan hệ phụ thuộc dài hạn và ngữ cảnh hai chiều, cho phép mô hình hiểu được sự phát triển của hư hỏng theo thời gian thay vì chỉ dựa vào một điểm dữ liệu đơn lẻ. Nhờ sự kết hợp này, mô hình 1DCNN-BiGRU và kỹ thuật AUG có khả năng học các mẫu dữ liệu phức tạp, xác định sự tương tác giữa các đặc trưng cục bộ và nắm bắt hiệu quả các xu hướng theo thời gian, từ đó nâng cao độ chính xác trong việc phát hiện hư hỏng.

3. THÔNG TIN VỀ BỘ DỮ LIỆU

3.1. Giới thiệu cầu Cửa Rào


Cầu Cửa Rào nằm tại Km360+450, huyện Vũ Quang, tỉnh Hà Tĩnh (Hình 3), bắc qua sông Ngàn Sâu và thuộc tuyến đường sắt Bắc-Nam, đưa vào sử dụng năm 2013. Cầu gồm ba nhịp giản đơn bằng thép: hai nhịp giàn thép dài 66,4 m và một nhịp dầm thép chữ I dài 32m. Hệ chịu lực chính là giàn tam giác - dạng kết cấu phổ biến ở các cầu đường sắt Việt Nam. Mặt cắt ngang rộng 8.8 m, bố trí hai lối đi bộ hai bên (mỗi bên 2,2 m) và một đường sắt đơn rộng 4,8 m [18].



Hình 3. Cầu Cửa Rào, Hà Tĩnh.

3.2. Mô hình phần tử hữu hạn – FEM

Các thanh giàn có hình dạng và kích thước đa dạng, gồm chín nhóm mặt cắt được lựa chọn theo chức năng làm việc. Do toàn bộ nhịp đều là nhịp giản đơn, nghiên cứu này chọn một nhịp giàn thép - hệ chịu lực chính - làm đối tượng mô phỏng và chẩn đoán. Chúng tôi sẽ sử dụng phần mềm Matlab với hộp công cụ Stabill để xây dựng mô hình phần tử hữu hạn của cầu giàn thép Cửa Rào. Mô hình này sẽ sử dụng các phần tử dầm với mỗi nút có sáu bậc tự do (DOFs), liên kết tại nút giả thiết cứng. Trục X đại diện cho hướng dọc cầu, trục Y là hướng ngang cầu, và trục Z là hướng thẳng đứng. Các gối cầu được mô phỏng bằng cách sử dụng cả gối cô định và gối di động. Nhịp cầu được mô phỏng bằng vật liệu thép với môđun đàn hồi Young $2 \times 10^{11} \text{ N/m}^2$, khối lượng thể tích 7850 kg/m^3 và hệ số Poisson bằng 0,3.



Hình 4. Mô hình FEM cầu Cửa Rào.

Để đảm bảo mô hình số có thể đại diện chính xác cho cây cầu thật, cần phải cập nhật mô hình dựa trên dữ liệu đo đạc thực tế [19]. Các thông số sau khi cập nhật mô hình được thể hiện ở bảng 1. Mô hình cuối cùng gồm 53 nút và 143 phần tử được thể hiện trong hình 4.

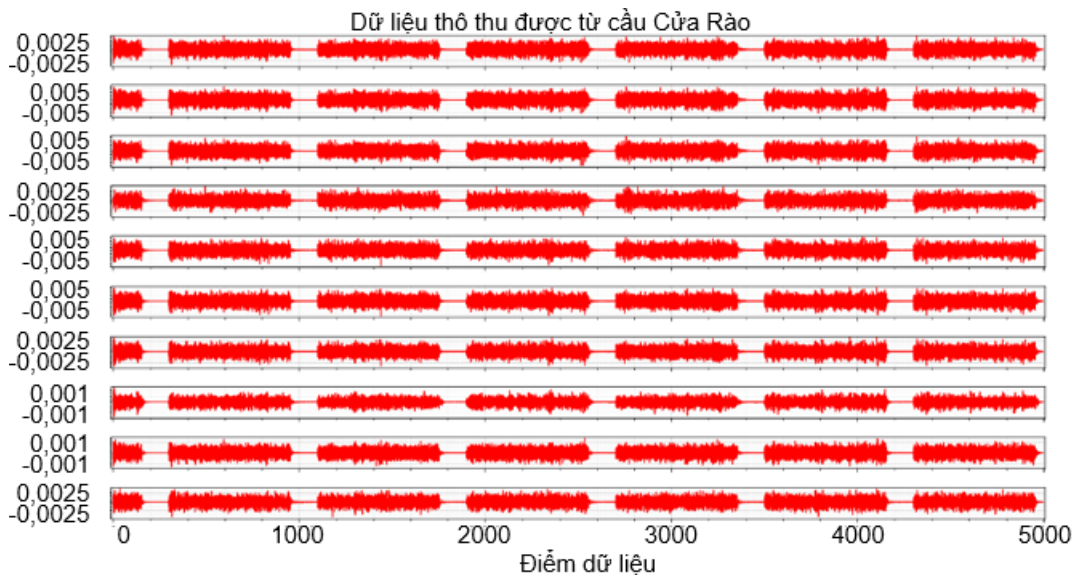
Bảng 1. Các kết quả sau khi cập nhật mô hình [19].

Mode	Tần số riêng (Hz)		
	Đo đạc	Trước khi cập nhật	Sau khi cập nhật
1	2,016	2,068	2,016
2	4,232	4,392	4,315
3	4,915	4,652	4,527
4	6,271	6,753	6,507
5	7,721	9,691	8,371

3.3. Tiền xử lí dữ liệu

Để thu được dữ liệu dao động phục vụ chẩn đoán hư hỏng, nghiên cứu cần một nguồn kích thích động lực học được kiểm soát là đoàn tàu có 3 trục cách nhau 5m, có tải trọng 15kN ở 2 trục đầu và 10kN ở trục cuối. Việc sử dụng một tải trọng không đối xứng là để tạo ra một môi trường có kiểm soát, đảm bảo rằng sự khác biệt trong tín hiệu giữa các kích bản là do hư hỏng gây ra, cho phép so sánh hiệu năng của các mô hình một cách công bằng.

Tàu có khoảng cách so với đầu cầu là 30m, vận tốc chạy là 100km/h và tần số lấy mẫu là 500Hz, lực xung kích tác động lên cầu là 500kN, số lần xe chạy của phương tiện trên cầu bằng 8. Có tất cả 28 cảm biến gia tốc ảo được sử dụng để trích xuất kết quả là gia tốc, chuyển vị theo thời gian sẽ được đặt tại các mặt cắt đặc trưng, trong đó mỗi cảm biến sẽ thu 50000 điểm dữ liệu. Một ví dụ về dữ liệu thu được tại 1 cảm biến ảo theo thời gian thể hiện trong hình 5.



Hình 5. Dữ liệu thô thu được từ cảm biến của cầu Cửa Rào.

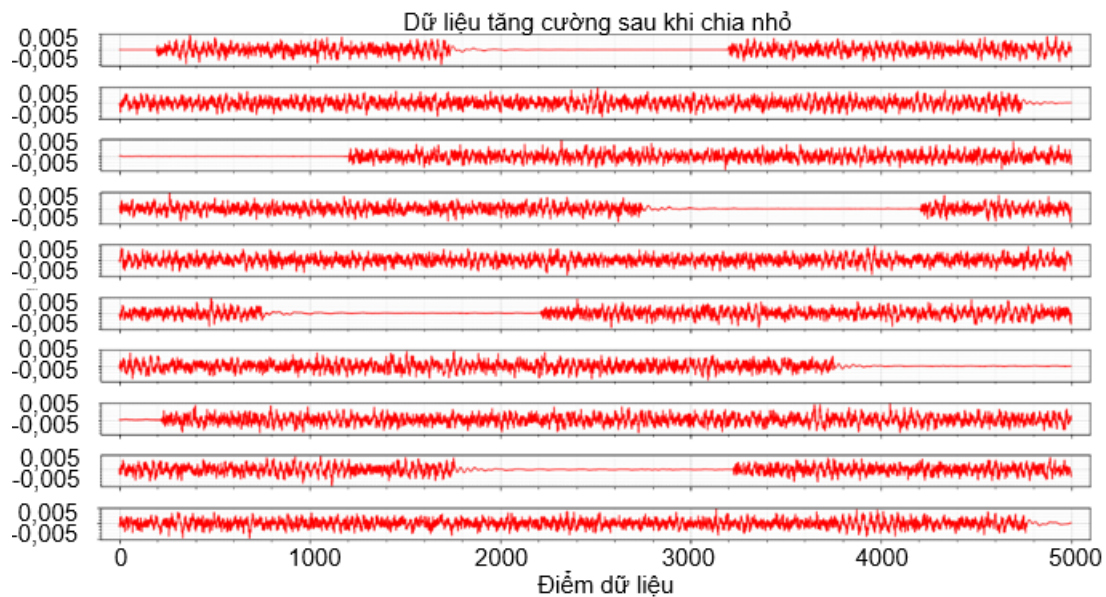
Trong nghiên cứu này, 11 kích bản hư hỏng được thiết lập (bảng 2); ở mỗi kích bản, phân tử và mức độ hư hỏng được gán nhãn cụ thể. Hư hỏng được mô phỏng bằng cách giảm độ cứng của phần tử bị ảnh hưởng. Ví dụ, “hư hỏng 20% tại phần tử 2” nghĩa là mô đun đàn hồi (E) của phần tử đó giảm 20%. Sự suy giảm độ cứng này làm thay đổi rõ rệt đáp ứng kết cấu dưới tải trọng động. Cách tiếp cận này phản ánh thực tế các cơ chế hư hỏng như nứt, ăn mòn, quá tải, vốn đều làm giảm độ cứng cục bộ, kéo theo suy giảm khả năng chịu lực và biến đổi đặc trưng

dao động (tần số riêng, dạng dao động). Mục tiêu chính của nghiên cứu là so sánh hiệu năng của kiến trúc đề xuất với các mô hình nền tảng. Do đó, việc sử dụng các kịch bản hư hỏng được xác định trước và rõ ràng như trên là cần thiết để tạo ra một cơ sở nhất quán cho việc đánh giá và đảm bảo tính công bằng. Từ 11 kịch bản này, bộ dữ liệu ban đầu thu được từ mô hình sẽ có dạng (11, 28, 50000).

Bảng 2. Các kịch bản hư hỏng được thiết lập.

Nhãn	0	1	2	3	4	5	6	7	8	9	10
Phần tử	0	1	2	3	4	5	6	39	40	41	42
Hư hỏng (%)	0	10	20	30	40	30	10	20	10	30	10

Sau đó, chúng tôi tiền xử lý dữ liệu bằng kỹ thuật AUG và chia nhỏ. Đầu tiên, dữ liệu được tăng cường dữ liệu nhằm mở rộng quy mô và đa dạng, bắt chước các yếu tố tác động trong thực tế cũng như khắc phục tình trạng thiếu hụt dữ liệu, với các kỹ thuật: lật, đảo ngược, thêm nhiễu, cắt ghép cửa sổ. Bộ dữ liệu ban đầu được mở rộng từ (11, 28, 50000) thành (44, 28, 50000) sau khi áp dụng AUG. Tiếp theo, chúng tôi tiến hành chia nhỏ đoạn dữ liệu dài 50000 thành 10 tập dữ liệu có độ dài 5000, do đó tập dữ liệu AUG sau khi chia nhỏ (Hình 6) sẽ có dạng (1232 = 44 x 28, 10, 5000).



Hình 6. Dữ liệu sau tăng cường và chia nhỏ của cầu Cửa Rào.

Cuối cùng, tập dữ liệu này sẽ được chia thành 2 tập dữ liệu (huấn luyện và kiểm thử) với tỷ lệ 80:20 để đưa vào huấn luyện, do đó tập huấn luyện có dạng (985, 10, 5000) và tập kiểm thử có dạng (247, 10, 5000).

4. KẾT QUẢ VÀ ĐÁNH GIÁ


Trong mục này, bài báo trình bày kết quả của mô hình đề xuất và phân tích sâu hiệu năng cũng như độ chính xác của mô hình kết hợp 1DCNN-BiGRU với kỹ thuật AUG. Để có cái nhìn khách quan và toàn diện, mô hình kết hợp được so sánh với hai mô hình DL truyền thống khác gồm 1DCNN và BiGRU. Đây đều là các kiến trúc mạng phổ biến, đã chứng minh hiệu quả ở nhiều bài toán chuỗi thời gian. Toàn bộ quá trình huấn luyện được thực hiện trên máy tính với

cấu hình Windows 11 64-bit, CPU Intel Core i9- 13900HX, RAM 16GB, và GPU RTX GeForce 4060, VRAM 8GB. Môi trường lập trình sử dụng Python 3.10.13 và thư viện TensorFlow 2.10.0. Các tham số của mô hình đề xuất được thể hiện ở bảng 3.

Bảng 3. Bảng tổng hợp siêu tham số của mô hình 1DCNN-BiGRU.

Tham số	Giá trị	Lớp áp dụng	Chức năng
n_filters	512	Conv1D	Số lượng bộ lọc (đặc trưng) mà lớp CNN học.
kernel_size	8	Conv1D	Kích thước của cửa sổ trượt để thực hiện tích chập.
Activation	ReLU	Conv1D	Hàm kích hoạt sau lớp 1DCNN
MaxPooling1D	2	Conv1D	Giảm chiều dữ liệu và trích xuất các đặc trưng
n_units	64	BiGRU	Số lượng đơn vị (nút) trong mỗi lớp BiGRU.
dropout_rate	0.5	SpatialDropout1D, BiGRU	Tỷ lệ loại bỏ các kết nối để chống quá khớp.
optimizer	Adam	model.compile	Thuật toán tối ưu hóa để cập nhật trọng số.
learning_rate	1e-3	Adam	Tốc độ học, quyết định mức độ cập nhật trọng số.
loss	sparse categorical crossentropy	model.compile	Hàm mất mát cho bài toán phân loại nhiều lớp
metrics	accuracy	model.compile	Thước đo hiệu suất trong quá trình huấn luyện.


Trong quá trình huấn luyện trên tập kiểm thử (hình 7), mô hình 1DCNN-BiGRU cho kết quả vượt trội: độ chính xác nhanh chóng vượt 90% từ sau khoảng 15 bước lặp và duy trì ổn định quanh 92% - 95%; đồng thời độ mất mát thấp nhất (khoảng 0,30-0,35) và biên động nhỏ, phản ánh năng lực khái quát tốt. Mặt khác, mô hình 1DCNN hội tụ ổn định nhưng sớm đạt trạng thái hội tụ ở độ chính xác thấp hơn (khoảng 84%-86%) với độ mất mát khoảng 0,45-0,55, cho thấy mô hình nắm bắt tốt đặc trưng cục bộ nhưng hạn chế ở phụ thuộc thời gian dài. BiGRU kém nhất: chính xác chỉ gần 82%-86% và dao động mạnh; độ mất mát cao gần 1,2-1,8 và nhiều đỉnh, biểu hiện học chậm, nhạy siêu tham số và khó trích chọn đặc trưng cục bộ khi không có 1DCNN hỗ trợ.




Hình 7. Biểu đồ độ chính xác và mất mát trên tập kiểm thử.

Để đánh giá trực quan khả năng tách lớp của các biểu diễn đặc trưng, nghiên cứu này áp dụng phương pháp đánh giá nhúng láng giềng ngẫu nhiên với phân phối t (t-distributed

Stochastic Neighbor Embedding - t-SNE) nhằm để kiểm tra hiện tượng chồng lấn cụm và mức độ phân cụm giữa các mô hình. Một số hình ảnh t-SNE của 3 mô hình được thể hiện ở hình 8-9 sau các bước lặp đầu và cuối.



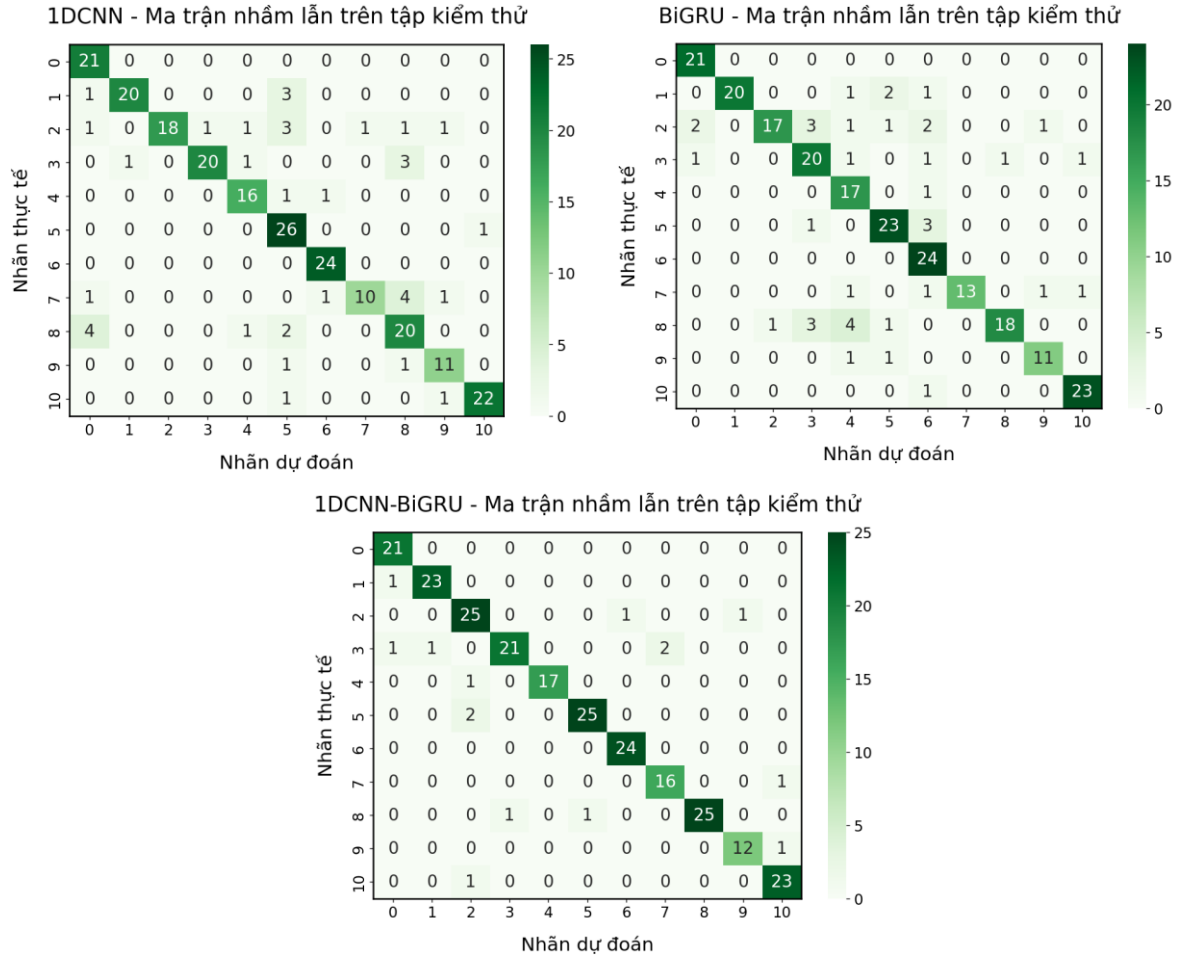
Hình 8. Biểu đồ trực quan hóa t-SNE của 3 mô hình sau bước lặp 0.



Hình 9. Biểu đồ trực quan hóa t-SNE của 3 mô hình sau bước lặp 99.

Qua hai mốc bước lặp 0 và 99, biểu đồ t-SNE cho thấy 1DCNN–BiGRU tạo được biểu diễn phân cụm nhất: các cụm cùng màu ngày càng cô đặc, ranh giới rõ và rộng, nhiều nội cụm nhỏ; 1DCNN đạt mức phân nhóm khá sau 99 bước lặp nhưng vẫn còn chồng lấn giữa một số lớp, phản ánh việc nắm bắt đặc trưng chủ yếu ở mức cục bộ; trong khi BiGRU giữ phân bố rời rạc và lan tỏa, phân cụm kém cô đặc, xen lẫn đáng kể - dấu hiệu của biểu diễn chưa ổn định. Tính bền vững theo thời gian học cũng tốt nhất ở mô hình lai (hình dạng cụm ít biến dạng), 1DCNN cải thiện chậm, còn BiGRU biến thiên thất thường.

Để minh họa hiệu năng trên tập kiểm thử, chúng tôi sử dụng ma trận nhầm lẫn (hình 10). Trong ba mô hình, 1DCNN–BiGRU hoạt động tốt nhất có đường chéo chính, các ô ngoài đường chéo rất nhỏ và thưa, hầu hết nhãn đạt số dự đoán đúng cao (khoảng 21–25 điểm), chỉ còn nhầm lẫn nhẹ ở các nhãn 5, 6, 8 và 9 với 1-2 điểm. Trong khi đó, 1DCNN đứng thứ hai, vẫn duy trì đường chéo rõ nhưng xuất hiện các cụm nhầm lẫn đáng kể ở nhãn 1, 6 và 10 lên đến 3-4 điểm, cho thấy mô hình chủ yếu bắt được đặc trưng cục bộ, kém vững ở phụ thuộc thời gian dài. BiGRU kém nhất với lỗi phân tán rộng khắp, nhiều ô ngoài đường chéo có giá trị 2–4, phản ánh biểu diễn tuần tự chưa đủ mạnh khi thiếu trích chọn đặc trưng cục bộ



Hình 10. Ma trận nhầm lẫn trên tập kiểm thử được huấn luyện bởi 3 mô hình.

Ngoài ra để đánh giá định lượng, chúng tôi so sánh hiệu năng của mô hình kết hợp với các mô hình đơn lẻ trên tập kiểm thử (bảng 4) sử dụng các thước đo suy ra từ nhãn chuẩn (ground truth) dựa theo kết quả thu được từ ma trận nhầm lẫn theo các công thức (6)–(9).

$$\text{precision} = \frac{TP}{TP + FP} \quad (6)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (7)$$

$$\text{f1 - score} = \frac{2 \times \text{recall} \times \text{precision}}{\text{recall} + \text{precision}} \quad (8)$$

$$\text{accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

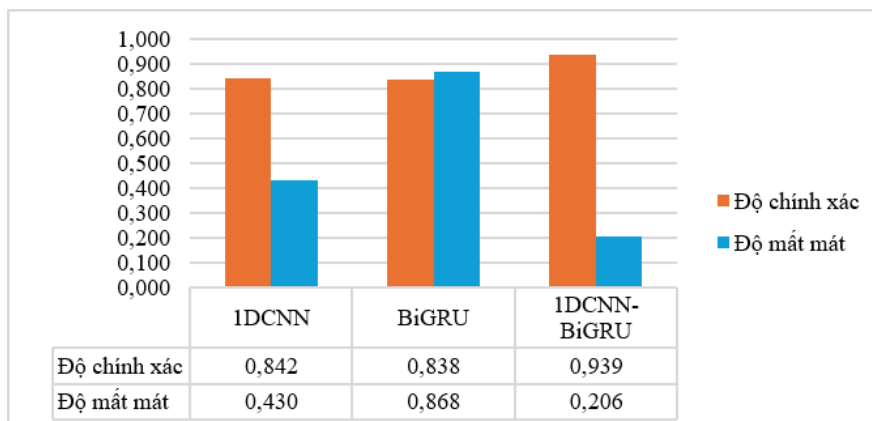
Trong đó: precision đo tỷ lệ dự đoán dương mà đúng, recall đo mức bao phủ các mẫu dương thực, f1 – score là chỉ số cân bằng giữa precision và recall và accuracy là tỷ lệ dự đoán đúng trên toàn bộ mẫu. Ngoài ra, TP, TN, FP, FN lần lượt là số mẫu dương đúng, âm đúng, dương giả, âm giả.

Bảng 4. Kết quả huấn luyện của 3 mô hình trên tập kiểm thử.

Nhãn	1DCNN			BiGRU			1DCNN-BiGRU		
	precision	recall	f1-score	precision	recall	f1-score	precision	recall	f1-score
0	0,750	1,000	0,857	0,875	1,000	0,933	0,913	1,000	0,955
1	0,952	0,833	0,889	1,000	0,833	0,909	0,958	0,958	0,958
2	1,000	0,667	0,800	0,944	0,630	0,756	0,862	0,926	0,893
3	0,952	0,800	0,870	0,741	0,800	0,769	0,955	0,840	0,894
4	0,842	0,889	0,865	0,654	0,944	0,773	1,000	0,944	0,971
5	0,703	0,963	0,813	0,821	0,852	0,836	0,962	0,926	0,943
6	0,923	1,000	0,960	0,706	1,000	0,828	0,960	1,000	0,980
7	0,909	0,588	0,714	1,000	0,765	0,867	0,889	0,941	0,914
8	0,690	0,741	0,714	0,947	0,667	0,783	1,000	0,926	0,962
9	0,786	0,846	0,815	0,846	0,846	0,846	0,923	0,923	0,923
10	0,957	0,917	0,936	0,920	0,958	0,939	0,920	0,958	0,939
accuracy	0,842			0,838			0,939		

Từ bảng 4, có thể thấy kết quả nhất quán với đánh giá định tính trước đó, qua đó khẳng định ưu thế của 1DCNN-BiGRU kết hợp kỹ thuật AUG vượt trội rõ rệt so với 1DCNN và BiGRU với accuracy tổng thể đạt 0,939 (so với 0,842 và 0,838). Với chỉ số f1-score, mô hình đề xuất nổi bật ở nhãn 4, 6, 8 lớn 0,96, với chỉ precision đạt 1 ở các nhãn 4 và 8, và chỉ số recall tối đa ở nhãn 0 và 6. Trong đó, 1DCNN có điểm mạnh ở nhãn 6 và 10 nhưng nhầm lẫn ở nhãn 7 và 8 BiGRU cân bằng hơn 1DCNN ở một số nhãn (0,1,10) nhưng recall thấp ở 2, 3, 8 (f1-score chỉ 0,756–0,783).

Cuối cùng, độ hiệu quả của mô hình còn được đánh giá qua độ chính xác và độ mất mát được thể hiện trong hình 11. Có thể thấy mô hình đề xuất hoạt động tốt nhất, với độ chính xác cao nhất là 93,9% và độ mất mát thấp nhất là 0,206 trên tập kiểm tra. Mặt khác, mô hình đơn lẻ 1DCNN và BiGRU có hiệu suất thấp hơn đáng kể, với mô hình BiGRU đạt độ chính xác là 83,8% và độ mất mát cao nhất là 0,868, và mô hình 1DCNN có độ chính xác là 84,2% và độ mất mát 0,430. Điều này cho thấy rằng mô hình BiGRU học tốt các mối quan hệ tuần tự, nhưng ít hiệu quả hơn khi không được kết hợp với các lớp tích chập. Sự khác biệt đáng kể về độ mất mát và độ chính xác giữa các mô hình cũng cho thấy tầm quan trọng của việc chọn đúng kiến trúc mô hình để tối ưu hóa hiệu suất trên các tập dữ liệu phức tạp.



Hình 11. Độ chính xác và mất mát của các mô hình.

5. KẾT LUẬN

Nghiên cứu này áp dụng DL cho chuẩn đoán hư hỏng kết cấu cầu giàn thép. Từ các kết quả thu được, có thể rút ra các kết luận chính như sau:

- Mô hình 1DCNN-BiGRU kết hợp kỹ thuật AUG là mô hình tối ưu nhất cho bài toán phân loại với độ chính xác cao nhất 93,9% và độ mất mát thấp nhất (0,154) vượt trội hơn so với các mô hình khác như 1DCNN và BiGRU với độ chính xác lần lượt là 84,2% và 83,8%

- Sự kết hợp giữa mô hình học sâu BiGRU, 1DCNN và kỹ thuật AUG mang lại hiệu suất rất tốt, qua đó mở ra khả năng ứng dụng rộng rãi trong nhiều lĩnh vực khác nhau, từ nhận diện khuôn mặt đến dự báo khí tượng nhờ vào khả năng linh hoạt và hiệu quả trong xử lý dữ liệu phức tạp. Điều này chứng tỏ rằng việc kết hợp các mô hình có thể mang lại những cải tiến đáng kể trong hiệu suất.

- Để nâng cao tính ứng dụng thực tiễn, các nghiên cứu trong tương lai sẽ tập trung mở rộng bộ dữ liệu bằng cách mô phỏng các loại hư hỏng đa dạng hơn, bao gồm hư hỏng đồng thời tại nhiều vị trí và các cơ chế hư hỏng phi tuyến tính.

- Hơn nữa, cần tiến hành các phân tích chi tiết về hiệu suất của mô hình trên các tình huống thực tế, từ đó có thể điều chỉnh và tối ưu hóa mô hình một cách hiệu quả. Việc tiếp tục cải tiến theo các định hướng này sẽ giúp khai thác tối đa tiềm năng của các mô hình kết hợp, tiến tới việc triển khai các hệ thống giám sát sức khỏe kết cấu tự động và hiệu quả.

LỜI CẢM ƠN

Nghiên cứu này được tài trợ bởi Trường Đại học Giao thông vận tải (ĐH GTVT) trong đề tài mã số T2025-CT-008TD.

TÀI LIỆU THAM KHẢO

- [1]. M. Habashneh, M. M. Rad, An Investigation of the Recent Developments in Reliability-based Structural Topology Optimization, *Period. Polytech. Civ. Eng.*, 67 (2023) 765–774. <https://doi.org/10.3311/PPci.22107>.
- [2]. T. T. Anh, H. H. Viet, T. D. Anh, N. T. Duc, Effect of adhesion failure and temperature on the mechanical behavior of orthotropic steel bridge deck, *Tạp Chí Khoa Học Giao Thông Vận Tải*, 73 (2022) 52–60. <https://doi.org/10.47869/tcsj.73.1.5>.
- [3]. Y. Zhang, W. Yang, A comparative study of the stochastic simulation methods applied in structural health monitoring, *Eng. Comput.*, 31 (2014) 1484–1513. <https://doi.org/10.1108/EC-07-2013-0185>.
- [4]. L. H. Viet, T. T. Thi, B. H. Xuan, Swarm intelligence-based technique to enhance performance of ANN in structural damage detection, *Tạp Chí Khoa Học Giao Thông Vận Tải*, 73 (2022) 1–15. <https://doi.org/10.47869/tcsj.73.1.1>.
- [5]. L. H. Viet, H. H. Vinh, T. V. Van, B. H. Xuan, An improved version of mode shape based indicator for structural damage identification, *Tạp Chí Khoa Học Giao Thông Vận Tải*, 74 (2023) 790–804. <https://doi.org/10.47869/tcsj.74.7.3>.
- [6]. J. Gao, S. Dong, J. Cui, M. Yuan, J. Zhao, DRN-GAN: an integrated deep learning-based health degradation assessment model for naval propulsion system, *Eng. Comput.*, 39 (2022) 2306–2325. <https://doi.org/10.1108/EC-10-2021-0624>.

- [7]. H. Chen, Z. Du, X. Li, H. Zhou, Z. Liu, Identification of pipe inner surface in heat conduction problems by deep learning and effective thermal conductivity transform, *Eng. Comput.*, 37 (2020) 3505–3523. <https://doi.org/10.1108/EC-01-2020-0012>.
- [8]. T. V. Manh, H. T. Ngoc, M. T. Duc, L. B. Phuc, L. N. Duc, An Effective Damage Detection Approach for a Truss Bridge Using a Hybrid Deep Learning Model, *Proceedings of the 5th International Conference on Sustainability in Civil Engineering - Volume 2*, 2025, Springer, pp. 91–101. https://doi.org/10.1007/978-981-96-5206-8_10.
- [9]. N. C. Thi Nguyen, T. M. Vu, Damage detection in structural health monitoring using BiLSTM-1DCNN hybrid network: a case study on a large-scale steel truss bridge, *Eng. Comput.*, 42 (2025) 2226–2242. <https://doi.org/10.1108/EC-08-2024-0714>.
- [10]. P. P. Arya, S. Mohammad Reza, A. Augusta, B. Bambang, Estimation of structural response using convolutional neural network: application to the Suramadu bridge, *ResearchGate*, <https://doi.org/10.1108/EC-12-2020-0695>.
- [11]. S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, D. J. Inman, 1D convolutional neural networks and applications: A survey, *Mech. Syst. Signal Process.*, 151, (2021) 107398. <https://doi.org/10.1016/j.ymsp.2020.107398>.
- [12]. J. Duan, H. Zhao, W. Qin, M. Qiu, M. Liu, News Text Classification Based on MLCNN and BiGRU Hybrid Neural Network, *trong 2020 3rd International Conference on Smart BlockChain (SmartBlock)*, Zhengzhou, China: IEEE, 2020, pp. 1–6. <https://doi.org/10.1109/SmartBlock52591.2020.00032>.
- [13]. Z. Zha, J. He, L. Zhen, M. Yu, C. Dong, Z. Li, G. Wu, H. Zuo, K. Peng, A BiGRU Model Based on the DBO Algorithm for Cloud-Edge Communication Networks, *Appl. Sci.*, 14 (2024) 10155. <https://doi.org/10.3390/app142210155>.
- [14]. B. A. Krohling, R. A. Krohling, 1D Convolutional neural networks and machine learning algorithms for spectral data classification with a case study for Covid-19, 2023, arXiv: arXiv:2301.10746. <https://doi.org/10.48550/arXiv.2301.10746>.
- [15]. W. Tang, G. Long, L. Liu, T. Zhou, M. Blumenstein, J. Jiang, Omni-Scale CNNs: a simple and effective kernel size configuration for time series classification, 2022, arXiv: arXiv:2002.10061. <https://doi.org/10.48550/arXiv.2002.10061>.
- [16]. J. Chung, C. Gulcehre, K. Cho, Y. Bengio, Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling, 2014, arXiv: arXiv:1412.3555. <https://doi.org/10.48550/arXiv.1412.3555>.
- [17]. S. H. Noh, Analysis of Gradient Vanishing of RNNs and Performance Comparison, *Information*, 12 (2021) 442. <https://doi.org/10.3390/info12110442>.
- [18]. T. Le Xuan, T. Nguyen Chi, T. Bui Tien, H. Tran Ngoc, ResUNet4T: A potential deep learning model for damage detection based on a numerical case study of a large-scale bridge using time-series data, *Eng. Struct.*, 340 (2025) 120668. <https://doi.org/10.1016/j.engstruct.2025.120668>.
- [19]. Q. H. Nguyen, T. X. Le, D. L. M. Nguyen, T. T. Bui, N. C. Nguyen, H. N. Tran, A Prospective Technique for Damage Detection in Truss Structures Using the Fusion of DNN with AVOA, *KSCE J. Civ. Eng.*, 28 (2024) 2920–2933. <https://doi.org/10.1007/s12205-024-1968-5>.